

基于 TSB-HMM 模型的雷达高分辨距离像目标识别方法

潘勉* 王鹏辉 杜兰 刘宏伟 保铮

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘要: 针对雷达高分辨距离像(HRRP)的识别问题, 该文提出了一种基于时域特征的截断 Stick-Breaking 过程隐马尔可夫模型(TSB-HMM), 并建立了基于 TSB-HMM 模型的分层识别算法, 利用 TSB-HMM 模型结合时域特征和功率谱特征对 HRRP 进行分层识别。实测数据的实验结果表明, 该方法是一种有效的雷达 HRRP 识别方法, 分层识别的算法可极大提高目标的平均识别率。特别是在训练样本数极少的情况下, TSB-HMM 模型仍能获得较好的识别性能。

关键词: 雷达目标识别; 高分辨距离像; 截断 Stick-Breaking 隐马尔可夫模型; 分层识别

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2013)07-1547-08

DOI: 10.3724/SP.J.1146.2012.01190

Radar HRRP Target Recognition Based on Truncated Stick-breaking Hidden Markov Model

Pan Mian Wang Peng-hui Du Lan Liu Hong-wei Bao Zheng

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: To improve the performance of radar High-Resolution Range Profile (HRRP) target recognition, a new Truncated Stick-Breaking Hidden Markov Model (TSB-HMM) based on time domain feature is proposed. Moreover, a hierarchical classification scheme based on TSB-HMM is employed, which utilizes both time domain feature and power spectral density feature of HRRPs for hierarchical recognition. Experimental results based on measured data show that the TSB-HMM is an effective method for radar HRRP recognition, and the hierarchical classification scheme can largely enhance the average recognition rate. Furthermore, the proposed method can obtain satisfactory recognition performances even with very limited training data.

Key words: Radar Automatic Target Recognition (RATR); High-Resolution Range Profile (HRRP); Truncated Stick-Breaking Hidden Markov Model (TSB-HMM); Hierarchical classification

1 引言

雷达高分辨距离像(HRRP)是用宽带雷达信号获取的目标散射点子回波在雷达视线方向投影的矢量和, 它包含了目标的尺寸和散射点分布等重要结构信息, 并且易于获取和快速处理。因此, 利用 HRRP 进行目标识别成为当前研究的热点^[1-4]。

基于隐马尔可夫模型(HMM)的统计识别是一种重要的 HRRP 识别方法, 目前已有不少文献进行相关研究并取得了一定成效^[2,3]。该方法的原理是先在训练阶段使用 HMM 模型对由多个 HRRP 样本构成的观测序列统计建模, 然后在测试阶段采用最大后验概率准则来判定测试序列所属的目标类别。实

际应用中, 该方法在存在以下问题: (1)该方法将每个 HRRP 看作是高维空间中的观测点, 对高维 HRRP 构成的序列建模, 由于这种方法所需的计算量和内存资源过大, 在实际工程中难以实现, 因此需要通过对高维的 HRRP 数据降维来减轻计算资源负担。文献[2]利用 relax 算法来提取 HRRP 中散射中心的位置信息作为特征, 先将多个 HRRP 样本的特征构成序列, 然后建立 HMM 模型描述该特征序列, 文献[3]中联合 HRRP 散射中心位置与幅度信息构成低维特征, 并建立了非平稳的 HMM 模型对该特征组成的序列建模。然而, 降维过程会不可避免地损失大量有用识别信息。(2)对多个 HRRP 样本组成的序列利用 HMM 模型建模隐含了一个条件: 即在测试阶段中, 目标相对雷达视线变化的角速度须和训练阶段保持一致, 否则就会导致训练阶段和测试阶段采样率不一致的问题, 而这一条件在实际中难以满足; (3)HMM 模型只能对由多个 HRRP 样本构成的观测序列进行识别, 对高速运动的非合作目

2012-09-12 收到, 2012-12-17 改回

国家自然科学基金(61271024, 61201292, 61201283), 新世纪优秀人才支持计划(NCET-09-09-0630), 全国优秀博士学位论文作者专项资金(FANEDD201156)和中央高校基本科研业务费专项资金联合资助课题

*通信作者: 潘勉 roy1022@foxmail.com

标(如敌方战斗机类目标)雷达很难进行持续跟踪检测,导致识别算法失效。由于这些问题的存在,大大限制了 HMM 模型的识别性能和应用范围。

为了解决以上问题,本文提出了一种基于时域特征的截断 Stick-Breaking 过程隐马尔可夫模型(Truncated Stick-Breaking Hidden Markov Model, TSB-HMM)的 HRRP 识别方法,并以此为基础进一步构建了基于 TSB-HMM 模型的分层识别方法。该方法存在 4 个优点:首先,将单个 HRRP 的特征作为一个序列进行建模,利用了目标固有的空间物理结构特性;其次,TSB-HMM 模型采用单个 HRRP 的特征作为 1 维观测序列,相对于采用由多个 HRRP 的特征构成的高维观测序列的传统模型,TSB-HMM 模型中的参数维度比较低,这一特点不仅降低了模型对训练样本数的要求和减轻了模型的计算资源负担,而且无需对 HRRP 进行降维,有效地保留了大量有用识别信息;再次,TSB-HMM 模型将单个 HRRP 的特征作为 1 维观测序列,它避免了传统方法中存在的训练和测试阶段须保证目标角速度变化一致的问题;最后该方法在距离像内建立 HMM 模型,只需一个 HRRP 的特征即可实现识别,识别算法对测试样本数更加稳健。基于实测数据的实验结果表明,本文方法有效地提高了目标的正确识别率,并且在训练样本数极少的情况下,仍能表现出较好的识别性能。

2 应用时域特征的 TSB-HMM

2.1 时域特征提取

应用 TSB-HMM 进行识别时,首先要从 HRRP 样本中提取其时域特征作为 TSB-HMM 的观测序列。高分辨雷达的波长一般远小于雷达目标的尺寸,此时目标的电磁散射特性可以用散射中心模型来描述。根据该模型,目标的 HRRP 是一个复向量,可以表示为 $\mathbf{h} = [h_1, h_2, \dots, h_L]^T$, 其中上标 T 表示转置操作符, h_l 表示第 l 个距离单元的子回波, L 表示 HRRP 中距离单元个数。

HRRP 的时域特征 \mathbf{x} 可通过对 HRRP 进行取模操作得到,即

$$\mathbf{x} = |\mathbf{h}| = [x_1, x_2, \dots, x_L]^T \quad (1)$$

该特征非常直观地反映了目标的尺寸和散射点分布等物理结构特性,所以它被广泛应用于雷达目标分类中^[5,6]。

提取完 HRRP 的时域特征之后,下面分 3 个步骤介绍 TSB-HMM: 首先回顾传统的 HMM 模型,然后介绍应用时域特征的 TSB-HMM 和传统 HMM 的区别及其构造过程,最后说明在给定观测序列时

如何用变分贝叶斯(VB)算法^[7]确定 TSB-HMM 的最优模型参数 $\Phi^* = \{\mathbf{W}^*, \mathbf{w}_0^*, \theta^*\}$ 。

2.2 HMM 回顾

HMM 模型是一种描述序列统计特性的参数化概率模型^[8],它是一个双重随机模型,由两部分组成:一部分是一条隐马尔可夫链构成的隐含层,另一部分是实际观测序列构成的观测层。

设 HMM 由随机过程 $\{(s_n, x_n), n \geq 1\}$ 组成,其中 $\{x_n, n \geq 1\}$ 表示观测序列, x_n 是第 n 个观测值, $\{s_n, n \geq 1\}$ 表示有限状态隐马尔可夫链, s_n 表示观测值 x_n 所对应的状态。隐马尔可夫模型可由参数集 $\Phi = \{\mathbf{W}, \mathbf{w}_0, \theta\}$ 表示,其中 \mathbf{W} 和 \mathbf{w}_0 是描述隐状态的参数, $\mathbf{W} = \{\mathbf{w}_i\}_{i=1}^I$, $\mathbf{w}_i = \{w_{i,j}\}_{j=1}^I$, $w_{i,j}$ 表示隐状态 i 转移到隐状态 j 的转移概率, I 表示隐状态的总数, $\mathbf{w}_0 = \{w_{0,i}\}_{i=1}^I$, $w_{0,i}$ 表示隐马尔可夫链中初始状态为隐状态 i 的概率, $\theta = \{\theta_i\}_{i=1}^I$ 表示观测值所服从概率分布的参数,最常见的观测值服从的分布形式是高斯分布。

HMM 在训练阶段主要解决以下问题:给定观测序列 $\{x_n, n \geq 1\}$, 估计产生此观测序列概率 $P(\{\mathbf{x}\}_{i=1}^{N_0} | \Phi)$ 最大的 HMM 模型的最优模型参数 $\Phi^* = \{\mathbf{W}^*, \mathbf{w}_0^*, \theta^*\}$ 。传统的 HMM 在训练前需指定隐状态的总数 I (即参数 \mathbf{W} 和 \mathbf{w}_0 的维数),而指定隐状态总数 I 给定的正确与否直接决定了最终的识别性能。为了避免这一问题,本文采用基于 TSB-HMM 的 HRRP 识别方法,该方法能够在估计参数集 Φ 的同时,自动确定隐状态个数。

2.3 TSB-HMM 的构造

TSB-HMM 是一种特殊的 HMM 模型,它是无限状态 Stick-Breaking 隐马尔可夫模型(SB-iHMM)^[9]的有限状态实现形式。在 TSB-HMM 中,状态转移矩阵 \mathbf{W} 的每一行和初始状态概率矩阵 \mathbf{w}_0 服从 Stick-Breaking 非参数先验,而传统 HMM 没有这样的非参数先验形式。TSB-HMM 可以在模型训练过程中预先给定一个远大于实际用到的隐状态个数 I , 然后利用 Stick-Breaking 非参数先验的稀疏性从中选取用到的隐状态,整个过程无须确定隐状态数,从而避免了传统 HMM 中手动确定隐状态数的问题。

给定一组 HRRP 时域特征 $\{\mathbf{x}^n\}_{n=1}^N$, 其中 N 表示时域特征个数,则基于时域特征的 TSB-HMM 构造过程可参照图 1 所示,其中下标 i 和 l 分别表示该参数是对应于隐状态 i 和距离单元 l 的,矩形框表示存在一组被矩形框选中的变量,变量的个数等于矩形框右下角标记的个数。其中隐状态个数为 I , 时域样本集一共有 N 个样本,每个样本内包含距离单元有 L 个。




图1 TSB-HMM 的图形表示

首先, 在 TSB-HMM 中, 每一个时域特征 $\mathbf{x}^n = [x_1^n, \dots, x_l^n, \dots, x_L^n]^T$ 都被视为一个 1 维观测序列, 其中观测值 x_l^n 表示第 n 个时域特征中第 l 个距离单元的回波幅度。严格地说, 各距离单元回波幅度观测值近似服从瑞利分布并具有“长尾效应”, 在实际工程中为了简化模型复杂度和降低计算量, 广泛采用距离单元回波幅度观测值服从高斯分布这一假设^[1,6]。因此在 TSB-HMM 中, 假设各观测值都服从高斯分布, 记为

$$x_l^n \sim f(\theta_{s_l^n}), \quad l = 1, \dots, L, \quad n = 1, \dots, N \quad (2)$$

其中 $f(\cdot)$ 表示高斯分布, s_l^n 表示 x_l^n 所对应的状态, $\theta_{s_l^n}$ 表示状态 s_l^n 对应高斯分布的均值和方差。然后, TSB-HMM 中对应于观测值 x_l^n 的状态 s_l^n 依赖于初始状态概率矩阵 \mathbf{w}_0 和上一个观测值的状态 s_{l-1}^n 对应的转移概率矩阵 $\mathbf{w}_{s_{l-1}^n}$:

$$s_1^n \sim \mathbf{w}_0, \quad s_l^n \sim \mathbf{w}_{s_{l-1}^n}, \quad l = 2, \dots, L, \quad n = 1, \dots, N \quad (3)$$

继而, 如前文所述状态转移矩阵 \mathbf{W} 的每一行 \mathbf{w}_i ($i = 1, \dots, I$) 和初始状态概率矩阵 \mathbf{w}_0 服从 Stick-Breaking 先验:

$$\mathbf{w}_i | \beta_i \sim \mathcal{S}(\beta_i), \quad i = 0, \dots, I \quad (4)$$

其中 $\mathcal{S}(\cdot)$ 表示 Stick-Breaking 过程^[10], 其参数 β_i 服从伽马分布:

$$\beta_i | a_\alpha, b_\alpha \sim \mathbf{Ga}(a_\alpha, b_\alpha), \quad i = 0, \dots, I \quad (5)$$

其中 $\mathbf{Ga}(a_\alpha, b_\alpha)$ 表示参数为 a_α 和 b_α 的伽马分布。为了使后验完全取决于训练数据, 超参数先验对后验学习基本不提供信息, 通常 a_α 和 b_α 被确定为一个很小的值(如 10^{-6})。最后为了保证下文所述用于确定模型参数后验分布的变分贝叶斯(VB)算法中参数的先验分布和后验分布的形式保持一致的共轭性这一前提条件, 令观测值概率密度函数的参数服从高斯伽马先验 H ^[6]:

$$\theta_i \sim H, \quad i = 1, \dots, I \quad (6)$$

至此基于时域特征的 TSB-HMM 构造完成。

从基于时域特征的 TSB-HMM 构建过程中可以看出时域特征具有以下优点: (1) 由于各观测值 x_l^n 是一个数而不再是传统方法中所用的高维向量, 因此

它要求的计算资源负担比较小, 并且避免了特征降维带来的信息丢失问题; (2) TSB-HMM 模型将单个 HRRP 的时域特征作为 1 维观测序列避免了多个 HRRP 时域特征构成的序列时存在的训练和测试阶段须保证目标速度方向与雷达视线夹角的角速度变化一致这个问题; (3) 在 TSB-HMM 的识别过程中, 单个距离像时域特征即为一个观测序列, 也就是说, 只用单个距离像的时域特征即可进行识别。

2.4 VB 算法

构建完 TSB-HMM 之后, 本节将使用 VB 算法进行模型参数估计。VB 算法通过迭代地更新 TSB-HMM 的所有参数 $\Phi_0 = \{\Phi = \{\{\mathbf{w}_i\}_{i=1}^I, \mathbf{w}_0, \{\theta_i\}_{i=1}^I, \{s_l^n\}_{n=1, l=1}^{N, L}, \{\beta_i\}_{i=1}^I\}$ 来最大化模型边缘似然函数的下界 F , 最终获取 TSB-HMM 模型的最优模型参数 $\Phi^* = \{\mathbf{W}^*, \mathbf{w}_0^*, \theta^*\}$, 其中 $\mathbf{W}^* = \{\mathbf{w}_i^*\}_{i=1}^I$, $\theta^* = \{\theta_i^*\}_{i=1}^I$ 。给定一组时域特征 $\{\mathbf{x}^n\}_{n=1}^N$, 模型的对数似然函数可以表示为

$$\begin{aligned} \ln p(\{\mathbf{x}^n\}_{n=1}^N) &= \ln \int p(\{\mathbf{x}^n\}_{n=1}^N, \Phi_0) d\Phi_0 \\ &\geq \int q(\Phi_0) \ln \frac{p(\{\mathbf{x}^n\}_{n=1}^N, \Phi_0)}{q(\Phi_0)} d\Phi_0 = F \quad (7) \end{aligned}$$

其中 $p(\{\mathbf{x}^n\}_{n=1}^N, \Phi_0)$ 和 $q(\Phi_0)$ 可表示为

$$\begin{aligned} p(\{\mathbf{x}^n\}_{n=1}^N, \Phi_0) &= \left[\prod_{i=0}^I p(\beta_i | a_\alpha, b_\alpha) \right] \\ &\quad \cdot \left[\prod_{i=0}^I p(\mathbf{w}_i | \beta_i) \right] \left[\prod_{i=1}^I p(\theta_i) \right] \\ &\quad \cdot p(s_1^n | \mathbf{w}_0) \left[\prod_{i=1}^I p(s_l^n | s_{l-1}^n, \{\mathbf{w}_i\}_{i=0}^I) \right] \\ &\quad \cdot \prod_{n=1}^N \prod_{l=1}^L p(x_l^n | s_l^n, \{\theta_i\}_{i=1}^I) \end{aligned} \quad (8)$$

限于篇幅, 我们略去 VB 算法的具体推导过程, 下面给出该算法的具体步骤:

步骤 1 设置超参数 $a_\alpha = 10^{-6}, b_\alpha = 10^{-6}$, 中止门限 $\varepsilon = 10^{-5}$, 给隐状态个数 I 设定一个足够大的初始值。

步骤 2 更新 $q(\theta_i)$:

$$\begin{aligned} q(\theta_i) &\propto \exp \left[\ln H(\theta_i | \tilde{\theta}_i) + \sum_{n=1}^N \sum_{l=1}^L \langle s_{l,i}^n \rangle \ln f(x_l^n | \theta_i) \right], \\ & \quad i = 1, \dots, I \quad (9) \end{aligned}$$

其中 \propto 表示正比于, $\tilde{\theta}_i$ 是高斯伽马分布 $H(\cdot)$ 中的后验参数, $\langle s_{l,i}^n \rangle$ 表示 s_l^n 对应于第 i 个状态的期望, $\langle \cdot \rangle$ 表示求尖括号内部变量的期望, $f(x_l^n | \theta_i)$ 表示一个以

θ_i 为参数的高斯分布对应于点 x_i^n 的概率密度。

步骤3 令 $q(\beta_i) = \mathbf{Ga}(\tilde{a}_\alpha^{(i)}, \tilde{b}_\alpha^{(i)})$, 按式(10)更新超参数 $\tilde{a}_\alpha^{(i)}, \tilde{b}_\alpha^{(i)}$:

$$\left. \begin{aligned} \tilde{a}_\alpha^{(i)} &= a_\alpha + I - 1 \\ \tilde{b}_\alpha^{(i)} &= b_\alpha - \sum_{j=1}^{I-1} \left(\psi(\tilde{\beta}_{i,j}|_2) - \psi(\tilde{\beta}_{i,j}|_1 + \tilde{\beta}_{i,j}|_2) \right) \\ & \quad i=1, \dots, I \end{aligned} \right\} \quad (10)$$

其中 $\psi(a) = \text{d} \ln \Gamma(a) / \text{d}a$, 它是对伽马函数 $\Gamma(a)$ 取对数再求导以后所得, 其中 $\tilde{a}_\alpha^{(i)}, \tilde{b}_\alpha^{(i)}$ 表示对应于 β 中第 i 个元素的超参数。

步骤4 更新 $q(\mathbf{w}_0)$ 和 $\{q(\mathbf{w}_i)\}_{i=1}^I$:

$$\left. \begin{aligned} q(\mathbf{w}_0) &= \mathbf{S}(\tilde{\beta}_0|_1, \tilde{\beta}_0|_2) \\ q(\mathbf{w}_i) &= \mathbf{S}(\tilde{\beta}_i|_1, \tilde{\beta}_i|_2), \quad i=1, \dots, I \end{aligned} \right\} \quad (11)$$

参数 $\{\tilde{\beta}_{k_1|k_2} = [\tilde{\beta}_{k_1,1|k_2}, \tilde{\beta}_{k_1,2|k_2}, \dots, \tilde{\beta}_{k_1,I-1|k_2}]^T\}_{k_1=0, k_2=0}^{I,1}$ 的更新公式为

$$\left. \begin{aligned} \tilde{\beta}_{0,j}|_1 &= 1 + \sum_{n=1}^N \langle s_{1,j}^n \rangle \\ \tilde{\beta}_{0,j}|_2 &= \frac{\tilde{a}_\alpha^{(0)}}{\tilde{b}_\alpha^{(0)}} + \sum_{n=1}^N \sum_{z=j+1}^I \langle s_{1,z}^n \rangle \end{aligned} \right\} \quad j=1, \dots, I-1 \quad (12)$$

$$\left. \begin{aligned} \tilde{\beta}_{i,j}|_1 &= 1 + \sum_{n=1}^N \sum_{l=2}^L \langle s_{l-1,i}^n \rangle \langle s_{l,j}^n \rangle \\ \tilde{\beta}_{i,j}|_2 &= \frac{\tilde{a}_\alpha^{(i)}}{\tilde{b}_\alpha^{(i)}} + \sum_{n=1}^N \sum_{z=j+1}^I \sum_{l=2}^L \langle s_{l-1,i}^n \rangle \langle s_{l,z}^n \rangle \\ & \quad i=1, \dots, I, \quad j=1, \dots, I-1 \end{aligned} \right\} \quad (13)$$

步骤5 按式(14)更新 $q(\mathbf{s}^n) = \prod_{i=1}^L q(s_i^n)$:

$$q(\mathbf{s}^n) \propto \exp \left(\ln \mathbf{w}_0 s_1^n + \sum_{l=1}^L \ln \mathbf{w}_l s_l^n s_{l+1}^n + \sum_{l=1}^L \ln f(x_l^n | \theta_{s_l^n}) \right), \quad n=1, \dots, N \quad (14)$$

其中, $\langle \ln \mathbf{w}_{i,j} \rangle = \sum_{h=1}^{j-1} [\psi(\tilde{\beta}_{i,h}|_2) - \psi(\tilde{\beta}_{i,h}|_1 + \tilde{\beta}_{i,h}|_2)] + [\psi(\tilde{\beta}_{i,j}|_1) - \psi(\tilde{\beta}_{i,j}|_1 + \tilde{\beta}_{i,j}|_2)]$, $i=0, \dots, I, j=1, \dots, I$ 。

步骤6 根据式(8)和式(9)计算下界 F 。

步骤7 反复更新步骤2~步骤6, 直至满足 $|F_\tau - F_{\tau-1}| / |F_\tau| \leq \varepsilon$ 时算法中止。其中 F_τ 和 $F_{\tau-1}$ 分别为当前第 τ 次更新计算得到的下界和上一次更新计算得到的下界。

算法中止之后, 通过第 τ 次更新的参数, 计算并保存 TSB-HMM 模型的最优模型参数 $\Phi^* = \{\mathbf{W}^*, \mathbf{w}_0^*, \theta^*\}$, 最优状态转移矩阵 $\mathbf{W}^* = \{\mathbf{w}_i^*\}_{i=1}^I = \{\langle \mathbf{w}_i \rangle\}_{i=1}^I$, 最优初始状态概率向量 $\mathbf{w}_0^* = \langle \mathbf{w}_0 \rangle$ 和最优观测层概率分布参数 $\theta_i^* = \langle \theta_i \rangle$ 。

3 应用时域特征的 TSB-HMM 雷达目标识别步骤

根据文献[5]可知, 雷达目标的原始 HRRP 数据存在姿态敏感性, 强度敏感性和平移敏感性, 这些敏感性对模型的识别性能影响很大。所以在使用 TSB-HMM 进行识别之前, 需要对雷达目标的原始 HRRP 训练数据进行角域分帧、能量归一化以及包络对齐等预处理操作。

应用时域特征的 TSB-HMM 雷达目标 HRRP 识别系统包括训练阶段和测试阶段。其中训练阶段的任务是利用雷达目标 HRRP 的时域特征建立统计模型, 并估计统计模型中的各参数; 测试阶段的任务是由训练阶段得到的各目标的模型计算测试 HRRP 样本对应于各目标模型的后验概率值, 并将样本归类到具有最大后验概率值的模型所对应的目标类别中。训练阶段和测试阶段的具体步骤如下所示:

(1) 训练阶段:

步骤1 先将第 c 类目标 ($c=1, 2, \dots, C$) 的训练样本均匀分为 M_c 帧, 每一帧包含 N 个训练样本, 然后将训练样本做能量归一化和包络对齐处理, 完成训练阶段的预处理步骤。

步骤2 提取各帧训练样本的时域特征作为识别特征, 记为 $\{\mathbf{x}^{(c,m)}\}_{c=1, m=1}^C, M_c$, 其中 $\mathbf{x}^{(c,m)}$ 表示第 c 个目标第 m 帧的训练样本的时域特征, C 为总目标数, M_c 为第 c 个目标的总帧数。

步骤3 对各类目标的各帧样本 $\{\mathbf{x}^{(c,m)}\}_{c=1, m=1}^C, M_c$ 使用 TSB-HMM 分别建模, 然后利用 VB 算法估计模型参数 $\{\Phi^{(c,m)}\}_{c=1, m=1}^C, M_c = \{\{\mathbf{w}_i^{(c,m)}\}_{i=1}^I, \theta^{(c,m)}, \mathbf{w}_0^{(c,m)}\}_{c=1, m=1}^C, M_c$, 其中 $\mathbf{w}_i^{(c,m)}$ 表示对应于第 c 个目标第 m 帧的状态转移矩阵的第 i 行, $\theta^{(c,m)}$ 表示对应于第 c 个目标第 m 帧的观测层概率分布参数, $\mathbf{w}_0^{(c,m)}$ 表示对应于第 c 个目标第 m 帧的初始状态概率矩阵。

步骤4 训练完毕以后保存模型参数 $\{\Phi^{(c,m)}\}_{c=1, m=1}^C, M_c$, 建立训练模板库。

(2) 测试阶段:

步骤1 对给定的测试样本能量归一化处理, 完成测试阶段的预处理步骤;

步骤2 提取测试样本的时域特征, 记为 $\mathbf{x}_{\text{test}} = [x_{\text{test},1}, x_{\text{test},2}, \dots, x_{\text{test},l}, \dots, x_{\text{test},L}]^T$, 其中 $x_{\text{test},l}$ 表示 \mathbf{x}_{test} 中第 l 个元素。

步骤3 利用 TSB-HMM 计算测试样本的时域特征对应于各目标每一帧的条件似然函数值, 其中对应于第 c 个目标第 m 帧的条件似然函数值可表示为

$$p(\mathbf{x}_{\text{test}} | c, m) = \sum_{\mathbf{S}} \left\langle w_{0, s_1^{(c,m)}}^{(c,m)} \right\rangle \prod_{l=2}^L \left\langle w_{s_{l-1}^{(c,m)}, s_l^{(c,m)}}^{(c,m)} \right\rangle \cdot \prod_{l=1}^L f^{(c,m)} \left(x_{\text{test}, l} \left| \left\langle \theta_{s_l^{(c,m)}}^{(c,m)} \right\rangle \right. \right) \quad (15)$$

其中 $\left\langle w_{0, s_1^{(c,m)}}^{(c,m)} \right\rangle$ 表示对应于第 c 个目标第 m 帧初始状态概率矩阵的后验期望, $\left\langle w_{s_{l-1}^{(c,m)}, s_l^{(c,m)}}^{(c,m)} \right\rangle$ 表示在第 c 个目标第 m 帧中从状态 $s_{l-1}^{(c,m)}$ 到状态 $s_l^{(c,m)}$ 的转移概率的后验期望, $\left\langle \theta_{s_l^{(c,m)}}^{(k,m)} \right\rangle$ 表示在第 c 个目标第 m 帧中状态 $s_l^{(k,m)}$ 对应的观测层概率分布参数的后验期望, 变量下标中的 l 表示变量对应于时域特征中的第 l 个距离单元。条件似然函数值 $p(\mathbf{x}_{\text{test}} | c, m)$ 可以通过前向后向算法^[8]计算。

步骤 4 计算测试样本对应于各类目标的条件似然值 $\{p(\mathbf{x}_{\text{test}} | c)\}_{c=1}^C$:

$$p(\mathbf{x}_{\text{test}} | c) = \max_m p(\mathbf{x}_{\text{test}} | c, m), \quad m = 1, \dots, M_c \quad (16)$$

步骤 5 将测试样本分类到最大目标条件似然值所对应的目标 c_0 中:

$$c_0 = \arg \max_c p(\mathbf{x}_{\text{test}} | c), \quad c = 1, \dots, C \quad (17)$$

其中 $\arg \max_c p(\mathbf{x}_{\text{test}} | c)$ 表示取最大的目标条件似然值 $p(\mathbf{x}_{\text{test}} | c)$ 所对应的 c 值。

4 分层识别

在实际中, 如果某些雷达目标的时域特征可分性不强, 会导致时域特征的平均识别性能不理想。为了改善这种情况下 TSB-HMM 的识别性能, 本节引入分层识别的思想, 提出基于 TSB-HMM 的分层识别算法。该算法引入功率谱特征, 以提高雷达目标的平均识别率。HRRP 的功率谱特征可以表示为

$$\mathbf{y} = |\text{FFT}(\mathbf{x})|^2 = \left[\sum_{l=1}^L x_l e^{-j2\pi l \times 1/L} \right]^2, \left[\sum_{l=1}^L x_l e^{-j2\pi l \times 2/L} \right]^2, \dots, \left[\sum_{l=1}^L x_l e^{-j2\pi l \times L/L} \right]^2 \quad (18)$$

其中 $\text{FFT}(\cdot)$ 表示快速傅里叶变换。文献[11,12]表明 HRRP 的功率谱特征在雷达目标识别中也是一种非常有效的特征, 它所表现出来的频域空间性质和可分性不同于时域特征, 所以可用它对时域特征进行有效补充。当测试样本被时域特征分类到用时域特征可分性不强的类别中时, 可采用功率谱特征对测试样本进行重新分类, 从而改善整体识别性能。

分层识别的流程如图 2 所示, 实线框内表示训练阶段, 虚线框内表示测试阶段。在训练阶段先对所有目标建立时域特征模型, 然后结合分层识别的

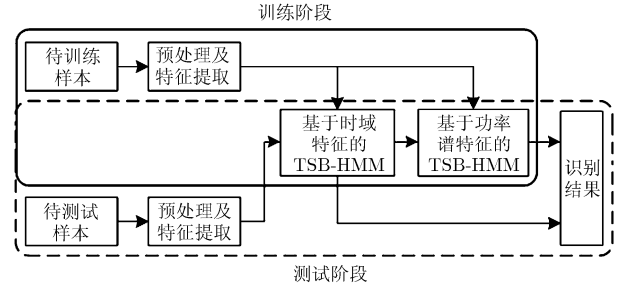


图 2 分层识别流程图

思想引入功率谱特征, 对时域可分性不强类别应用功率谱特征建立模型。在测试阶段, 如果应用时域特征将测试样本归类到用时域特征可分性较强的类别中, 就将分类结果保存为最终分类结果, 反之, 就应用功率谱特征模型对测试样本重新分类, 重新分类的结果保存为最终分类结果。

5 实验结果及分析

5.1 数据及实验设置介绍

本节的识别实验使用某 ISAR 雷达实测的 3 类飞机数据, 其中雷达和飞机的参数如表 1 所示, 3 类飞机的航迹在地面上的投影如图 3 所示。

表 1 ISAR 实验雷达和飞机参数

飞机	机长(m)	翼展(m)	机高(m)	雷达带宽(MHz)
安-26	23.80	26.20	9.83	400
奖状	14.40	15.90	4.57	400
雅克-42	36.38	34.88	9.83	400

由图 3 可见, 安-26 飞机和奖状飞机的 HRRP 数据分别划分为 7 段, 雅克-42 飞机的 HRRP 数据分为 5 段。本文分别在不同的数据段里选择训练和测试样本, 其中安-26 飞机的第 5 段和第 6 段, 奖状飞机实测数据的第 6 段和第 7 段, 雅克-42 的实测数据的第 2 段和第 5 段作为训练数据, 其余数据作为测试数据。从图 3 中可以看出训练数据包含了目标所有角域的信息。图 4(a)给出了 3 类目标的实测距离像的时域特征, 它反映了 3 类飞机的最本质的物理结构特性。图 4(b)是 3 类飞机实测距离像相对应的功率谱特征。

为了避免实测雷达目标 HRRP 数据的姿态敏感性问题, 所有实验采用角域分帧的方法。3 个目标的实测数据共分为 135 帧, 其中安-26 飞机的训练数据分为 50 帧, 奖状飞机的训练数据分为 50 帧, 雅克-42 的飞机训练数据分为 35 帧。设定 TSB-HMM 模型的隐状态个数 I 为一个足够大的初始值, 例如 $I = 25$ (当 $I \geq 25$ 时识别性能与 $I = 25$ 类似)。




图 3 3 类目标飞行航迹在地面投影

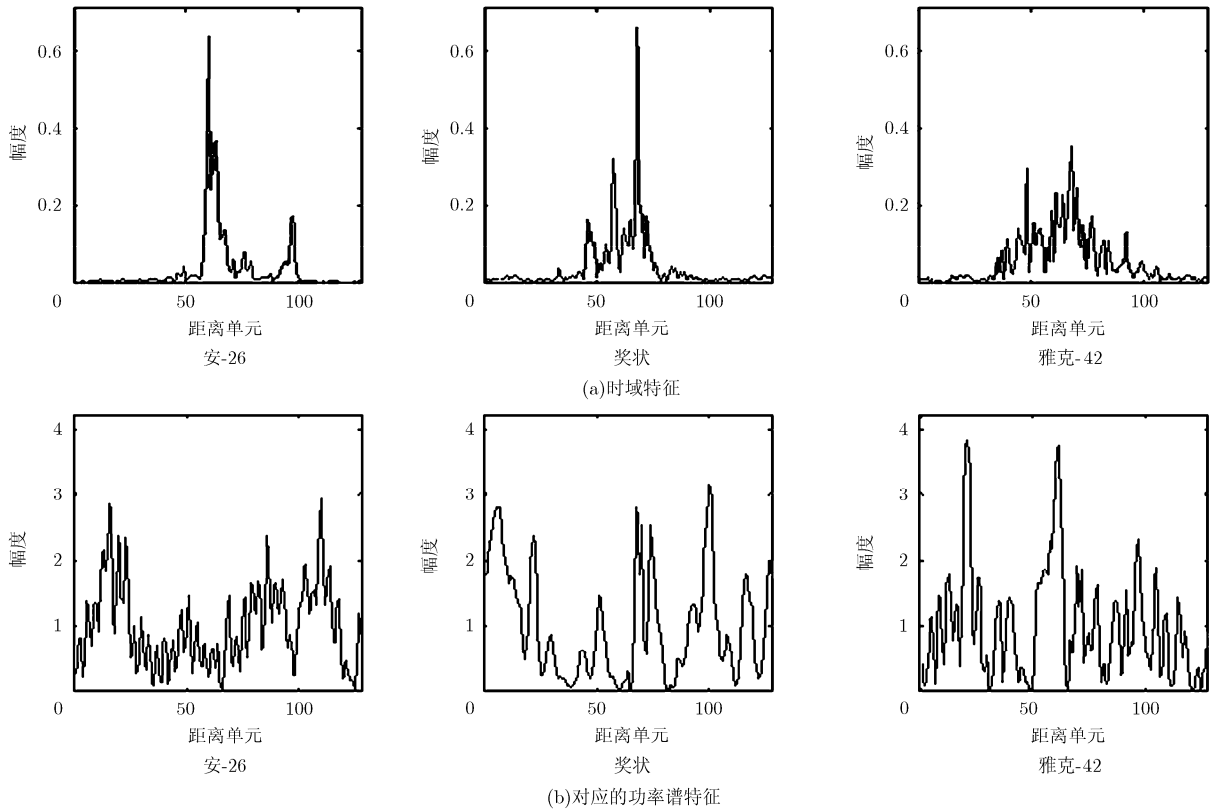


图 4 3 类飞机的一次实测距离像的时域特征及功率谱特征

5.2 基于时域特征和功率谱特征的 TSB-HMM 实验结果及分析

为了验证 TSB-HMM 模型以及高分辨目标距离像的时域特征和功率谱特征的有效性, 本节实验应用 TSB-HMM 模型对高分辨目标距离像的时域特征和功率谱特征分别建模检验识别性能。实验采用的雷达实测的 3 类飞机数据集包括 128×135 个 HRRP 样本, 其中训练样本集大小为 128×135 表示每一帧的训练数据包含 128 个 HRRP, 训练数据集一共包含 $128 \times 135 = 17280$ 个 HRRP。TSB-HMM 模型对 3 类实测目标 HRRP 的时域特征和功率谱特征识别的混淆矩阵如表 2 所示。从表中可以看出, TSB-HMM 模型能很有效地识别实测的 3 类飞机的数据。由于时域特征很直观地反映了目标的尺寸, 散射点分布

等物理结构信息, 用 TSB-HMM 模型可以很好地对这一本质的物理结构特性进行精确的描述, 时域特征的识别结果令人满意。相对于能表现本质物理结构特征的时域特征来说, 功率谱特征可分性要比时域特征差一些, 但是也可以对 3 类目标加以区分。应用时域特征识别时, 安-26 飞机的识别性能较好, 奖状飞机和雅克-42 飞机存在一定的混淆, 而在应用功率谱特征识别的时候, 情况恰恰相反, 奖状飞机和雅克-42 飞机在功率谱特征下可分性比较高。所以在某些雷达目标时域特征比较类似, 应用时域特征可分性不佳的情况下, 可以引入功率谱特征作为一种辅助特征进行分层识别, 进一步提高整体识别性能。

表 2 TSB-HMM 模型对 3 类飞机不同特征的识别结果(%)

128 × 135 个训练样本	基于时域特征的 TSB-HMM			基于功率谱特征的 TSB-HMM		
	安-26	奖状	雅克-42	安-26	奖状	雅克-42
安-26	98.9	2.3	0.1	77.7	39.7	3.7
奖状	1.1	72.9	10.8	2.3	58.4	0.2
雅克-42	0.1	24.6	89.2	20.0	1.9	96.1
平均识别率	87.0			77.4		

5.3 分层识别结果及分析

本实验采用 4.3 节所提出的基于 TSB-HMM 的分层识别算法对 3 类实测目标 HRRP 的时域特征和功率谱特征进行分层识别，实验数据集包括雷达实测的 3 类飞机 128 × 135 个 HRRP 训练样本。参考图 2 以及 5.2 节，在训练阶段，TSB-HMM 首先对所有目标高分辨目标距离像的时域特征建模，然后对奖状飞机和雅克-42 飞机高分辨目标距离像的功率谱特征建模；在测试阶段，如果应用时域特征将测试样本分类到安-26 飞机中，就将分类结果作为最终结果，如果分类到奖状飞机和雅克-42 飞机中，就应用功率谱特征模型对测试样本重新分类，并将重新分类的结果作为最终结果。TSB-HMM 的分层识别算法的混淆矩阵如表 3 所示。对比表 2 中只采用时域特征和功率谱特征的识别性能，分层识别算法大大提高了识别率。

表 3 基于 TSB-HMM 模型的分层识别算法对 3 类飞机的识别结果(%)

128 × 135 个训练样本	分层识别		
	安-26	奖状	雅克-42
安-26	98.9	2.3	0.1
奖状	1.1	92.6	0.4
雅克-42	0.1	4.9	99.6
平均识别率	97.0		

5.4 训练样本集大小对识别性能的影响

一个稳健的识别模型应当在训练样本数较少的情况下仍然能保持良好的识别性能。为了测试训练样本集的大小对测试结果的影响，实验中共使用了 8 个训练样本集，其大小分别为：1 × 135，2 × 135，4 × 135，8 × 135，16 × 135，32 × 135，64 × 135，128 × 135，其中 k × 135 表示每一帧内随机抽取 k 个 HRRP 做训练数据，训练数据集一共包含 k × 135 个 HRRP。本节采用这 8 个训练样本集，检验 TSB-HMM 模型对高分辨目标距离像的时域特征、功率谱特征以及这两种特征的分层识别算法在不同样本数目下的识别性能。最终结果如图 5 所示。




图 5 基于 TSB-HMM 模型的平均正确识别率随不同样本数的变化曲线

从图 5 中可以看出，模型的识别性能对于训练数据的减少具有鲁棒性。当选取的训练样本集为 8 × 135 时(即每一帧内随机抽取 8 个 HRRP 做训练数据，训练数据集一共包含 8 × 135 = 1080 个 HRRP)，分别应用时域特征和功率谱特征的 TSB-HMM 识别率可以达到 80.5%和 77.2%，应用 TSB-HMM 分层识别算法结合两种特征的识别率可以达到 91.9%。另外，即使在选取的训练样本集为 1 × 135 的情况下，应用 TSB-HMM 分层识别算法结合两种特征的识别率仍然可以达到 86.7%。在每一帧内随机抽取 8 个以上 HRRP 做训练数据时，采用时域特征或者功率谱特征的 TSB-HMM 模型的识别性能基本不随训练样本数的减少而显著下降，在分层识别算法中，即使在每一帧内只随机抽取 1 个 HRRP 做训练数据也可保证识别率。因此在小样本训练的条件下，TSB-HMM 模型以及分层识别算法极大地降低了系统对训练样本数的需求，节约了建模成本。

6 结论

本文提出了一种适用于 HRRP 识别的截断 Stick-Breaking 过程隐马尔可夫模型，使用 HRRP 的时域特征进行识别。此外本文还基于这一模型引入分层识别算法，结合时域特征和功率谱特征提高识别性能。实验表明，采用时域特征的 TSB-HMM 在雷达高分辨目标识别中是一个很有效的模型，取得了较好的识别结果，并且结合时域特征和功率谱特征的分层算法可以进一步提高识别性能；此外 TSB-HMM 的识别性能受训练样本数影响较小，即使在小样本条件下，TSB-HMM 也能取得较高的识别率。

参考文献

- [1] Du L, Liu H, Wang P, *et al.* Noise robust radar HRRP target recognition based on multitask factor analysis with small training data size[J]. *IEEE Transactions on Signal Processing*, 2012, 60(7): 3546-3559.
- [2] Pei B and Bao Z. Multi-aspect radar target recognition method based on scattering centers and HMMs classifiers[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(3): 1067-1074.
- [3] Feng Z, Zhang X, Hu Y, *et al.* Nonstationary hidden Markov models for multiaspect discriminative feature extraction from radar targets[J]. *IEEE Transactions on Signal Processing*, 2007, 55(5): 2203-2213.
- [4] 艾小锋, 李永祯, 赵峰, 等. 基于多视角一维距离像序列的机动目标特征提取[J]. *电子与信息学报*, 2011, 33(12): 2846-2851.
Ai Xiao-feng, Li Yong-zhen, Zhao Feng, *et al.* Feature extraction of processing using multi-aspect observed HRRP sequences[J]. *Journal of Electronics & Information Technology*, 2011, 33(12): 2846-2851.
- [5] Shi L, Wang P, and Liu H, *et al.* Radar HRRP statistical recognition with local factor analysis by automatic Bayesian Ying-Yang harmony learning[J]. *IEEE Transactions on Signal Processing*, 2011, 59(2): 610-617.
- [6] Du L, Wang P, Liu H, *et al.* Bayesian spatiotemporal multitask learning for radar HRRP target recognition[J]. *IEEE Transactions on Signal Processing*, 2011, 59(7): 3182-3196.
- [7] Beal M J. Variational algorithms for approximate Bayesian inference[D]. [Ph.D. dissertation], Gatsby Computational Neuroscience Unit, University College London, 2003.
- [8] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. *Proceedings of the IEEE*, 1989, 77(2): 275-285.
- [9] Beal M J, Ghahramani Z, and Rasmussen C. The infinite hidden Markov model[C]. *Neural Information Processing Systems (NIPS)*, Vancouver Canada, 2002, 14: 577-584.
- [10] Paisley J and Carin L. Hidden Markov models with stick breaking priors[J]. *IEEE Transactions on Signal Processing*, 2009, 57(10): 3905-3917.
- [11] 张瑞, 魏玺章, 黎湘. 基于匹配度的闪烁HRRP谱特征分析[J]. *电子与信息学报*, 2012, 34(4): 891-897.
Zhang Rui, Wei Xi-zhang, and Li Xiang. Analyses of the spectra features of speckled HRRP based on the matching score[J]. *Journal of Electronics & Information Technology*, 2012, 34(4): 891-897.
- [12] Du L, Liu H, Bao Z, *et al.* Radar HRRP target recognition based on higher order spectra[J]. *IEEE Transactions on Signal Processing*, 2005, 53(7): 2359-2368.
- 潘 勉: 男, 1985年生, 博士生, 研究方向为雷达目标识别.
- 杜 兰: 女, 1980年生, 教授, 博士生导师, 研究方向为统计信号处理、雷达信号处理、机器学习及其在雷达目标检测与识别方面的应用.
- 刘宏伟: 男, 1971年生, 教授, 博士生导师, 雷达信号处理国家重点实验室主任, 研究方向为自适应信号处理、雷达信号处理、雷达目标识别等.
- 保 铮: 男, 1927年生, 教授, 博士生导师, 中国科学院院士, 中国电子学会会士, 研究方向为自适应信号处理、雷达信号处理、雷达目标识别等.